

多項式回歸方程式

①

情報量規準

①

(1) 統計的毛分儿

(2) 情報量規準

(3) 一般化情報量規準
GIC

②

一発表内容一

(1) 定義と性質

- 最尤法と最尤推定量
- K-L情報量
- 平均対数尤度とその推定量
- 情報量規準AIC

(2) 多項式回帰モデルを使った具体例

- AICで評価
- 次数選択の重要性について

$\theta = (\theta_1, \theta_2, \dots, \theta_q)'$ を持つ

$\{f_{\theta}(x); \theta \in \Theta\}$; 想定モデル

$g(x)$; 真のモデル

データを $x_n = \{x_1, x_2, \dots, x_n\}$ とすると、

対数尤度関数

$$l(\theta) = \sum_{a=1}^n \log f_{\theta}(x_a)$$

➡ 最大推定量 $\hat{\theta}$ を求める

④

$g(x)$: 真のモデル, 確率密度関数

$\{f_\theta(x); \theta \in \Theta\}$: 想定したモデル

KL 情報量

$$I(g; f_\theta) = E_g \left[\log \frac{g(x)}{f_\theta(x)} \right]$$

$$(i) I(g; f_\theta) \geq 0$$

$$(ii) I(g; f_\theta) = 0 \iff g(x) = f_\theta(x)$$

$$I(g; f_{\hat{\theta}}) = \frac{E_g[\log g(x)] - E_g[\log f_{\hat{\theta}}(x)]}{\hat{\theta} \text{に依存しない}}$$

平均対数尤度

データ $x_n = \{x_1, x_2, \dots, x_n\} : g(x)$ からの
ランダム標本

平均対数尤度の推定値

$$E_{\hat{g}}[\log f_{\hat{\theta}}(x)] \approx \frac{1}{n} \sum_{\alpha=1}^n \log f_{\hat{\theta}}(x_{\alpha})$$

最大対数尤度

$$1. E_g \left[\underbrace{\sum_{\alpha=1}^m \log \hat{\theta}(X_\alpha)}_{\text{最大対数尤度}} - m \underbrace{E_g \log \hat{\theta}(Z)}_{\text{平均対数尤度}} \right]$$


$\approx \underbrace{P}_{\text{バイアス}} \leftarrow$ 漸近的に

$$2. AIC = -2 \underbrace{\sum_{\alpha=1}^m \log \hat{\theta}(X_\alpha)}_{\text{最大対数尤度}} + 2P \quad \text{バイアス}$$

$$3. AIC = -2(\text{最大対数尤度}) + 2(\text{モデルの自由パラメータ数})$$

9

散布图



j	x_j	y_j
1	0.00	0.854
2	0.05	0.786
⋮	⋮	⋮
10	0.95	0.985

多項式回帰モデル

$$y_j = \beta_0 + \beta_1 x_j + \beta_2 x_j^2 + \dots + \beta_p x_j^p + \varepsilon_j$$

$j=1, \dots, 20, \varepsilon_j \sim N(0, \sigma^2)$

$$\begin{pmatrix} y_1 \\ \vdots \\ y_{20} \end{pmatrix} = \begin{pmatrix} 1 & x_1 & x_1^2 & \dots & x_1^p \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{20} & x_{20}^2 & \dots & x_{20}^p \end{pmatrix} \begin{pmatrix} \beta_0 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_{20} \end{pmatrix}$$

最小自乗推定量
は

$$\begin{pmatrix} \hat{\beta}_0 \\ \vdots \\ \hat{\beta}_p \end{pmatrix} = (X'X)^{-1}X' \begin{pmatrix} y_1 \\ \vdots \\ y_{20} \end{pmatrix}$$

$\hat{\beta}$

$$\text{AIC}_P = \underline{20(\log(2\pi) + 1) + 20 \log \hat{\sigma}^2}$$

-2(最大対数尤度)

$$+ 2(\underline{P+2})$$

自由パラメータ数 <math><math>

$$\frac{\beta_0, \dots, \beta_P \cdot \hat{\sigma}^2}{(P+1) + 1 = P+2}$$

$$\hat{\sigma}^2 = \frac{1}{20} \sum_{\alpha=1}^{20} (y_\alpha - \sum_{j=0}^P \hat{\beta}_j x_{\alpha j})^2$$

9

表 1: 多項式回帰モデルの推定結果

次数 p	$\hat{\sigma}^2$	AIC
1	0.002587	-56.3876
2	0.000922	-75.0268
3	0.000833	-75.0421
4	0.000737	-75.4969
5	0.000688	-74.8885
6	0.000653	-74.0041
7	0.000622	-72.8865
8	0.000607	-71.3793
9	0.000599	-69.6621

AIC は $P = 4$ が最小 ⑩

二のとき.

$$y_j = 0.835 - 1.068x_j + 3.716x_j^2$$

$$- 4.573x_j^3 + 2.14x_j^4 + \varepsilon_j$$

$$\varepsilon_j \sim N(0, 0.737 \times 10^{-3})$$

この操作を20回繰り返す

$(0.00, 0.854)$, $(0.05, 0.786)$, $(0.10, 0.706)$,
..., $(0.90, 0.971)$, $(0.95, 0.985)$


データを1つずつ省き、19個のデータを選択

$$\hat{\beta} = \begin{pmatrix} \hat{\beta}_0 \\ \vdots \\ \hat{\beta}_p \end{pmatrix} = (X'X)^{-1} X'y \text{ を推定}$$


$$y = \hat{\beta}_0 + \hat{\beta}_1 x + \dots + \hat{\beta}_p x^p \text{ を生成}$$

$p = 1, 4, 9$

$\rho = 9$ のとき



$\rho = 1$ のとき



$\rho = 4$ のとき

